BEST AVAILABLE COPY

PCT/JP2004/008087

日本国特許庁 JAPAN PATENT OFFICE

03.06.2004

REC'D 22 JUL 2004

WIPO

別紙添付の書類に記載されている事項は下記の出願書類に記載されている事項と同一であることを証明する。

This is to certify that the annexed is a true copy of the following application as filed with this Office.

出 願 年 月 日 Date of Application:

2003年 6月 5日

出 願 番 号 Application Number:

人

特願2003-160657

[ST. 10/C]:

[JP2003-160657]

出 願
Applicant(s):


株式会社ケンウッド

PRIORITY DOCUMENT

SUBMITTED OR TRANSMITTED IN COMPLIANCE WITH RULE 17.1(a) OR (b)

2004年 7月 8

特許庁長官 Commissioner, Japan Patent Office) (")



ページ: 1/E

【書類名】

特許願

【整理番号】

P07-975291

【提出日】

平成15年 6月 5日

【あて先】

特許庁長官 殿

【国際特許分類】

G10L 13/06

G10L 13/08

G10L 11/04

【発明者】

【住所又は居所】

東京都八王子市石川町2967-3 株式会社ケンウッ

ド内

【氏名】

佐藤 寧

【特許出願人】

【識別番号】

000003595

【氏名又は名称】

株式会社ケンウッド

【代理人】

【識別番号】

100095407

【弁理士】

【氏名又は名称】

木村 満

【手数料の表示】

【予納台帳番号】

038380

【納付金額】

21,000円

【提出物件の目録】

【物件名】

明細書 1

【物件名】

図面 1

【物件名】

要約書 1

【包括委任状番号】 9903184

【プルーフの要否】

要

【曹類名】 明細書

【発明の名称】 音声合成装置、音声合成方法及びプログラム

【特許請求の範囲】

【請求項1】

音片を表す音声データを複数記憶する記憶手段と、

文章を表す文章情報を入力し、当該文章を構成する音片の韻律を予測する韻律 予測手段と、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片 の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択する選 択手段と、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する合成手段と、

より構成されることを特徴とする音声合成装置。

【請求項2】

前記記憶手段は、音声データが表す音片のピッチの時間変化を表す実測韻律データを、当該音声データに対応付けて記憶しており、

前記選択手段は、各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片の波形を表しており、且つ、対応付けられている実測韻律データが表すピッチの時間変化が韻律の予測結果に最も近い音声データを選択する、ことを特徴とする請求項1に記載の音声合成装置。

【請求項3】


前記記憶手段は、音声データの読みを表す表音データを、当該音声データに対応付けて記憶しており、

前記選択手段は、前記文章を構成する音片の読みに合致する読みを表す表音データが対応付けられている音声データを、当該音片と読みが共通する音片の波形を表す音声データとして扱う、

ことを特徴とする請求項1又は2に記載の音声合成装置。

【請求項4】

前記文章を構成する音片のうち、前記選択手段が音声データを選択できなかっ



前記合成手段は、前記選択手段が選択した音声データ及び前記欠落部分合成手段が合成した音声データを互いに結合することにより、合成音声を表すデータを 生成する、

ことを特徴とする請求項1、2又は3に記載の音声合成装置。

【請求項5】

音片を表す音声データを複数記憶し、

文章を表す文章情報を入力して、当該文章を構成する音片の韻律を予測し、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片 の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択し、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する、

ことを特徴とする音声合成方法。

【請求項6】

コンピュータを、

音片を表す音声データを複数記憶する記憶手段と、

文章を表す文章情報を入力し、当該文章を構成する音片の韻律を予測する韻律 予測手段と、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片 の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択する選 択手段と、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する合成手段と、

して機能させるためのプログラム。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】

この発明は、音声合成装置、音声合成方法及びプログラムに関する。

[0002]

【従来の技術】

音声を合成する手法として、録音編集方式と呼ばれる手法がある。録音編集方式は、駅の音声案内システムや、車載用のナビゲーション装置などに用いられている。

録音編集方式は、単語と、この単語を読み上げる音声を表す音声データとを対応付けておき、音声合成する対象の文章を単語に区切ってから、これらの単語に対応付けられた音声データを取得してつなぎ合わせる、という手法である(例えば、特許文献1参照)。

[0003]

【特許文献1】

特開平10-49193号公報

[0004]

【発明が解決しようとする課題】

しかし、音声データを単につなぎ合わせた場合、音声データ同士の境界では通常、音声のピッチ成分の周波数が不連続的に変化する、等の理由で、合成音声が不自然なものとなる。

この問題を解決する手法としては、同一の音素を互いに異なった韻律で読み上げる音声を表す複数の音声データを用意し、一方で音声合成する対象の文章に韻律予測を施して、予測結果に合致する音声データを選び出してつなぎ合わせる、という手法が考えられる。

しかし、音声データを音素毎に用意して録音編集方式により自然な合成音声を 得ようとすると、音声データを記憶する記憶装置には膨大な記憶容量が必要とな る。また、検索する対象のデータの量も膨大なものとなる。

[0005]

この発明は、上記実状に鑑みてなされたものであり、簡単な構成で高速に自然な合成音声を得るための音声合成装置、音声合成方法及びプログラムを提供することを目的とする。

[0006]

【課題を解決するための手段】

上記目的を達成すべく、この発明の第1の観点にかかる音声合成装置は、

音片を表す音声データを複数記憶する記憶手段と、

文章を表す文章情報を入力し、当該文章を構成する音片の韻律を予測する韻律 予測手段と、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択する選択手段と、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する合成手段と、

より構成されることを特徴とする。

[0007]

前記記憶手段は、音声データが表す音片のピッチの時間変化を表す実測韻律データを、当該音声データに対応付けて記憶していてもよく、

前記選択手段は、各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片の波形を表しており、且つ、対応付けられている実測韻律データが表すピッチの時間変化が韻律の予測結果に最も近い音声データを選択するものであってもよい。

[0008]

前記記憶手段は、音声データの読みを表す表音データを、当該音声データに対 応付けて記憶していてもよく、

前記選択手段は、前記文章を構成する音片の読みに合致する読みを表す表音データが対応付けられている音声データを、当該音片と読みが共通する音片の波形を表す音声データとして扱うものであってもよい。

[0009]

前記音声合成装置は、前記文章を構成する音片のうち、前記選択手段が音声データを選択できなかった音片について、前記記憶手段が記憶する音声データを用いることなく、当該音片の波形を表す音声データを合成する欠落部分合成手段を備えていてもよく、



前記合成手段は、前記選択手段が選択した音声データ及び前記欠落部分合成手段が合成した音声データを互いに結合することにより、合成音声を表すデータを 生成するものであってもよい。

[0010]

また、この発明の第2の観点に係る音声合成方法は、

音片を表す音声データを複数記憶し、

文章を表す文章情報を入力して、当該文章を構成する音片の韻律を予測し、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片 の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択し、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する、

ことを特徴とする。

[0011]

また、この発明の第3の観点に係るプログラムは、

コンピュータを、

音片を表す音声データを複数記憶する記憶手段と、

文章を表す文章情報を入力し、当該文章を構成する音片の韻律を予測する韻律 予測手段と、

各前記音声データのうちから、前記文章を構成する音片と読みが共通する音片 の波形を表していて、且つ、韻律が予測結果に最も近い音声データを選択する選 択手段と、

選択された音声データを互いに結合することにより、合成音声を表すデータを 生成する合成手段と、


して機能させるためのものであることを特徴とする。

[0012]

【発明の実施の形態】

以下、図面を参照して、この発明の実施の形態を説明する。

図1は、この発明の実施の形態に係る音声合成システムの構成を示す図である。図示するように、この音声合成システムは、本体ユニットMと、音片登録ユニ



[0013]

本体ユニットMは、言語処理部1と、一般単語辞書2と、ユーザ単語辞書3と、音響処理部4と、検索部5と、伸長部6と、波形データベース7と、音片編集部8と、検索部9と、音片データベース10と、話速変換部11とにより構成されている。

[0014]

言語処理部1、音響処理部4、検索部5、伸長部6、音片編集部8、検索部9及び話速変換部11は、いずれも、CPU (Central Processing Unit)やDSP (Digital Signal Processor)等のプロセッサや、このプロセッサが実行するためのプログラムを記憶するメモリなどより構成されており、それぞれ後述する処理を行う。

なお、言語処理部1、音響処理部4、検索部5、伸長部6、音片編集部8、検索部9及び話速変換部11の一部又は全部の機能を単一のプロセッサが行うようにしてもよい。

[0015]

一般単語辞書 2 は、P R'OM (Programmable Read Only Memory) やハードディスク装置等の不揮発性メモリより構成されている。一般単語辞書 2 には、表意文字 (例えば、漢字など)を含む単語等と、この単語等の読みを表す表音文字 (例えば、カナや発音記号など)とが、この音声合成システムの製造者等によって、あらかじめ互いに対応付けて記憶されている。

[0016]

ユーザ単語辞書 3 は、EEPROM (Electrically Erasable/Programmable R ead Only Memory) やハードディスク装置等のデータ書き換え可能な不揮発性メモリと、この不揮発性メモリへのデータの書き込みを制御する制御回路とにより構成されている。なお、プロセッサがこの制御回路の機能を行ってもよく、言語処理部 1、音響処理部 4、検索部 5、伸長部 6、音片編集部 8、検索部 9 及び話速変換部 1 1 の一部又は全部の機能を行うプロセッサがユーザ単語辞書 3 の制御回路の機能を行うようにしてもよい。

ユーザ単語辞書 3 は、表意文字を含む単語等と、この単語等の読みを表す表音文字とを、ユーザの操作に従って外部より取得し、互いに対応付けて記憶する。 ユーザ単語辞書 3 には、一般単語辞書 2 に記憶されていない単語等とその読みを表す表音文字とが格納されていれば十分である。

[0017]

波形データベース 7 は、PROMやハードディスク装置等の不揮発性メモリより構成されている。波形データベース 7 には、表音文字と、この表音文字が表す単位音声の波形を表す波形データをエントロピー符号化して得られる圧縮波形データとが、この音声合成システムの製造者等によって、あらかじめ互いに対応付けて記憶されている。単位音声は、規則合成方式の手法で用いられる程度の短い音声であり、具体的には、音素や、VCV(Vowel-Consonant-Vowel)音節などの単位で区切られる音声である。なお、エントロピー符号化される前の波形データは、例えば、PCM(Pulse Code Modulation)されたデジタル形式のデータからなっていればよい。

[0018]

音片データベース10は、PROMやハードディスク装置等の不揮発性メモリより構成されている。

音片データベース10には、例えば、図2に示すデータ構造を有するデータが記憶されている。すなわち、図示するように、音片データベース10に格納されているデータは、ヘッダ部HDR、インデックス部IDX、ディレクトリ部DIR及びデータ部DATの4種に分かれている。

[0019]

なお、音片データベース10へのデータの格納は、例えば、この音声合成システムの製造者によりあらかじめ行われ、及び/又は、音片登録ユニットRが後述する動作を行うことにより行われる。

[0020]

ヘッダ部HDRには、音片データベース10を識別するデータや、インデックス部IDX、ディレクトリ部DIR及びデータ部DATのデータ量、データの形式、著作権等の帰属などを示すデータが格納される。

[0021]

データ部DATには、音片の波形を表す音片データをエントロピー符号化して得られる圧縮音片データが格納されている。

なお、音片とは、音声のうち音素1個以上を含む連続した1区間をいい、通常 は単語1個分又は複数個分の区間からなる。

また、エントロピー符号化される前の音片データは、上述の圧縮波形データの 生成のためエントロピー符号化される前の波形データと同じ形式のデータ (例えば、PCMされたデジタル形式のデータ) からなっていればよい。

[0022]

ディレクトリ部DIRには、個々の圧縮音声データについて、

- (A) この圧縮音片データが表す音片の読みを示す表音文字を表すデータ (音 片読みデータ)、
 - (B) この圧縮音片データが格納されている記憶位置の先頭のアドレスを表すデータ、
 - (C) この圧縮音片データのデータ長を表すデータ、
 - (D) この圧縮音片データが表す音片の発声スピード (再生した場合の時間長) を表すデータ (スピード初期値データ) 、
 - (E) この音片のピッチ成分の周波数の時間変化を表すデータ (ピッチ成分データ)、

が、互いに対応付けられた形で格納されている。(なお、音片データベース 1 0 の記憶領域にはアドレスが付されているものとする。)

[0023]

なお、図2は、データ部DATに含まれるデータとして、読みが「サイタマ」である音片の波形を表す、データ量1410hバイトの圧縮音片データが、アドレス001A36A6hを先頭とする論理的位置に格納されている場合を例示している。(なお、本明細書及び図面において、末尾に"h"を付した数字は16進数を表す。)

[0024]

なお、上述の(A)~(E)のデータの集合のうち少なくとも(A)のデータ

(すなわち音片読みデータ)は、音片読みデータが表す表音文字に基づいて決められた順位に従ってソートされた状態で(例えば、表音文字がカナであれば、五十音順に従って、アドレス降順に並んだ状態で)、音片データベース10の記憶領域に格納されている。

また、上述のピッチ成分データは、例えば、図示するように、音片のピッチ成分の周波数を音片の先頭からの経過時間の1次関数で近似した場合における、この1次関数の切片 β 及び勾配 α の値を示すデータからなっていればよい。(勾配 α の単位は例えば [へルツ/秒] であればよく、切片 β の単位は例えば [へルツ] であればよい。)

また、ピッチ成分データには更に、圧縮音片データが表す音片が鼻濁音化されているか否か、及び、無声化されているか否かを表す図示しないデータも含まれているものとする。

[0025]


インデックス部IDXには、ディレクトリ部DIRのデータのおおよその論理的位置を音片読みデータに基づいて特定するためのデータが格納されている。具体的には、例えば、音片読みデータがカナを表すものであるとして、カナ文字と、先頭1字がこのカナ文字であるような音片読みデータがどのような範囲のアドレスにあるかを示すデータ(ディレクトリアドレス)とが、互いに対応付けて格納されている。

[0026]

なお、一般単語辞書 2、ユーザ単語辞書 3、波形データベース 7 及び音片データベース 1 0 の一部又は全部の機能を単一の不揮発性メモリが行うようにしてもよい。

[0027]

音片登録ユニットRは、図示するように、収録音片データセット記憶部12と、音片データベース作成部13と、圧縮部14とにより構成されている。なお、音片登録ユニットRは音片データベース10とは着脱可能に接続されていてもよく、この場合は、音片データベース10に新たにデータを書き込むときを除いては、音片登録ユニットRを本体ユニットMから切り離した状態で本体ユニットM



[0028]

収録音片データセット記憶部12は、ハードディスク装置等のデータ書き換え 可能な不揮発性メモリより構成されている。

収録音片データセット記憶部12には、音片の読みを表す表音文字と、この音片を人が実際に発声したものを集音して得た波形を表す音片データとが、この音声合成システムの製造者等によって、あらかじめ互いに対応付けて記憶されている。なお、この音片データは、例えば、PCMされたデジタル形式のデータからなっていればよい。

[0029]

音片データベース作成部13及び圧縮部14は、CPU等のプロセッサや、このプロセッサが実行するためのプログラムを記憶するメモリなどより構成されており、このプログラムに従って後述する処理を行う。

[0030]

なお、音片データベース作成部13及び圧縮部14の一部又は全部の機能を単一のプロセッサが行うようにしてもよく、また、言語処理部1、音響処理部4、検索部5、伸長部6、音片編集部8、検索部9及び話速変換部11の一部又は全部の機能を行うプロセッサが音片データベース作成部13や圧縮部14の機能を更に行ってもよい。また、音片データベース作成部13や圧縮部14の機能を行うプロセッサが、収録音片データセット記憶部12の制御回路の機能を兼ねてもよい。

[0031]

音片データベース作成部13は、収録音片データセット記憶部12より、互い・ に対応付けられている表音文字及び音片データを読み出し、この音片データが表 す音声のピッチ成分の周波数の時間変化と、発声スピードとを特定する。

発声スピードの特定は、例えば、この音片データのサンプル数を数えることにより特定すればよい。

[0032]

一方、ピッチ成分の周波数の時間変化は、例えば、この音片データにケプスト



ラム解析を施すことにより特定すればよい。具体的には、例えば、音片データが表す波形を時間軸上で多数の小部分へと区切り、得られたそれぞれの小部分の強度を、元の値の対数(対数の底は任意)に実質的に等しい値へと変換し、値が変換されたこの小部分のスペクトル(すなわち、ケプストラム)を、高速フーリエ変換の手法(あるいは、離散的変数をフーリエ変換した結果を表すデータを生成する他の任意の手法)により求める。そして、このケプストラムの極大値を与える周波数のうちの最小値を、この小部分におけるピッチ成分の周波数として特定する。

[0033]

なお、ピッチ成分の周波数の時間変化は、例えば、特開2003-108172号公報に開示された手法に従って音片データをピッチ波形データへと変換してから、このピッチ波形データに基づいて特定するようにすると良好な結果が期待できる。具体的には、音片データをフィルタリングしてピッチ信号を抽出し、抽出されたピッチ信号に基づいて、音片データが表す波形を単位ピッチ長の区間へと区切り、各区間について、ピッチ信号との相関関係に基づいて位相のずれを特定して各区間の位相を揃えることにより、音片データをピッチ波形信号へと変換すればよい。そして、得られたピッチ波形信号を音片データとして扱い、ケプストラム解析を行う等することにより、ピッチ成分の周波数の時間変化を特定すればよい。


[0034]

一方、音片データベース作成部13は、収録音片データセット記憶部12より 読み出した音片データを圧縮部14に供給する。

圧縮部14は、音片データベース作成部13より供給された音片データをエントロピー符号化して圧縮音片データを作成し、音片データベース作成部13に返送する。

[0035]

音片データの発声スピード及びピッチ成分の周波数の時間変化を特定し、この音片データがエントロピー符号化され圧縮音片データとなって圧縮部14より返送されると、音片データベース作成部13は、この圧縮音片データを、データ部



[0036]

また、音片データベース作成部13は、書き込んだ圧縮音片データが表す音片の読みを示すものとして収録音片データセット記憶部12より読み出した表音文字を、音片読みデータとして音片データベース10の記憶領域に書き込む。

また、書き込んだ圧縮音片データの、音片データベース10の記憶領域内での 先頭のアドレスを特定し、このアドレスを上述の(B)のデータとして音片デー タベース10の記憶領域に書き込む。

また、この圧縮音片データのデータ長を特定し、特定したデータ長を、 (C) のデータとして音片データベース10の記憶領域に書き込む。

また、この圧縮音片データが表す音片の発声スピード及びピッチ成分の周波数の時間変化を特定した結果を示すデータを生成し、スピード初期値データ及びピッチ成分データとして音片データベース10の記憶領域に書き込む。

[0037]

次に、この音声合成システムの動作を説明する。

まず、言語処理部1が、この音声合成システムに音声を合成させる対象として ユーザが用意した、表意文字を含む文章 (フリーテキスト) を記述したフリーテ キストデータを外部から取得したとして説明する。

[0038]

なお、言語処理部 1 がフリーテキストデータを取得する手法は任意であり、例えば、図示しないインターフェース回路を介して外部の装置やネットワークから取得してもよいし、図示しない記録媒体ドライブ装置にセットされた記録媒体 (例えば、フロッピー (登録商標) ディスクや CD - R O M など) から、この記録媒体ドライブ装置を介して読み取ってもよい。また、言語処理部 1 の機能を行っているプロセッサが、自ら実行している他の処理で用いたテキストデータを、フリーテキストデータとして、言語処理部 1 の処理へと引き渡すようにしてもよい

[0039]

フリーテキストデータを取得すると、言語処理部1は、このフリーテキストに



含まれるそれぞれの表意文字について、その読みを表す表音文字を、一般単語辞書2やユーザ単語辞書3を検索することにより特定する。そして、この表意文字を、特定した表音文字へと置換する。そして、言語処理部1は、フリーテキスト内の表意文字がすべて表音文字へと置換した結果得られる表音文字列を、音響処理部4へと供給する。

[0040]

音響処理部4は、言語処理部1より表音文字列を供給されると、この表音文字列に含まれるそれぞれの表音文字について、当該表音文字が表す単位音声の波形を検索するよう、検索部5に指示する。

[0041]

検索部5は、この指示に応答して波形データベース7を検索し、表音文字列に含まれるそれぞれの表音文字が表す単位音声の波形を表す圧縮波形データを索出する。そして、索出された圧縮波形データを伸長部6へと供給する。

[0042]

伸長部6は、検索部5より供給された圧縮波形データを、圧縮される前の波形データへと復元し、検索部5へと返送する。検索部5は、伸長部6より返送された波形データを、検索結果として音響処理部4へと供給する。


音響処理部4は、検索部5より供給された波形データを、言語処理部1より供給された表音文字列内での各表音文字の並びに従った順序で、音片編集部8へと供給する。

[0043]

音片編集部 8 は、音響処理部 4 より波形データを供給されると、この波形データを、供給された順序で互いに結合し、合成音声を表すデータ(合成音声データ)として出力する。フリーテキストデータに基づいて合成されたこの合成音声は、規則合成方式の手法により合成された音声に相当する。

[0044]

なお、音片編集部 8 が合成音声データを出力する手法は任意であり、例えば、 図示しないD/A (Digital-to-Analog) 変換器やスピーカを介して、この合成 音声データが表す合成音声を再生するようにしてもよい。また、図示しないイン



[0045]

次に、音響処理部4が、外部より配信された、表音文字列を表すデータ(配信文字列データ)を取得したとする。(なお、音響処理部4が配信文字列データを取得する手法も任意であり、例えば、言語処理部1がフリーテキストデータを取得する手法と同様の手法で配信文字列データを取得すればよい。)

[0046]

この場合、音響処理部 4 は、配信文字列データが表す表音文字列を、言語処理部 1 より供給された表音文字列と同様に扱う。この結果、配信文字列データが表す表音文字列に含まれる表音文字に対応する圧縮波形データが検索部 5 により索出され、圧縮される前の波形データが伸長部 6 により復元される。復元された各波形データは音響処理部 4 を介して音片編集部 8 へと供給され、音片編集部 8 が、この波形データを、配信文字列データが表す表音文字列内での各表音文字の並びに従った順序で互いに結合し、合成音声データとして出力する。配信文字列データに基づいて合成されたこの合成音声データも、規則合成方式の手法により合成された音声を表す。

[0047]

次に、音片編集部8が、定型メッセージデータ、発声スピードデータ、及び照合レベルデータを取得したとする。

なお、定型メッセージデータは、定型メッセージを表音文字列として表すデータであり、発声スピードデータは、定型メッセージデータが表す定型メッセージの発声スピードの指定値(この定型メッセージを発声する時間長の指定値)を示すデータである。照合レベルデータは、検索部9が行う後述の検索処理における検索条件を指定するデータであり、以下では「1」、「2」又は「3」のいずれかの値をとるものとし、「3」が最も厳格な検索条件を示すものとする。

[0048]

また、音片編集部8が定型メッセージデータや発声スピードデータや照合レベルデータを取得する手法は任意であり、例えば、言語処理部1がフリーテキストデータを取得する手法と同様の手法で定型メッセージデータや発声スピードデータや照合レベルデータを取得すればよい。

[0049]

定型メッセージデータ、発声スピードデータ、及び照合レベルデータが音片編集部8に供給されると、音片編集部8は、定型メッセージに含まれる音片の読みを表す表音文字に合致する表音文字が対応付けられている圧縮音片データをすべて索出するよう、検索部9に指示する。

[0050]

検索部9は、音片編集部8の指示に応答して音片データベース10を検索し、該当する圧縮音片データと、該当する圧縮音片データに対応付けられている上述の音片読みデータ、スピード初期値データ及びピッチ成分データとを索出し、索出された圧縮波形データを伸長部6へと供給する。1個の音片につき複数の圧縮音片データが該当する場合も、該当する圧縮音片データすべてが、音声合成に用いられるデータの候補として索出される。一方、圧縮音片データを索出できなかった音片があった場合、検索部9は、該当する音片を識別するデータ(以下、欠落部分識別データと呼ぶ)を生成する。

[0051]

伸長部6は、検索部9より供給された圧縮音片データを、圧縮される前の音片データへと復元し、検索部9へと返送する。検索部9は、伸長部6より返送された音片データと、索出された音片読みデータ、スピード初期値データ及びピッチ成分データとを、検索結果として話速変換部11へと供給する。また、欠落部分識別データを生成した場合は、この欠落部分識別データも話速変換部11へと供給する。

[0052]

一方、音片編集部8は、話速変換部11に対し、話速変換部11に供給された音片データを変換して、当該音片データが表す音片の時間長を、発声スピードデ

ページ: 16/

ータが示すスピードに合致するようにすることを指示する。

[0053]

話速変換部11は、音片編集部8の指示に応答し、検索部9より供給された音片データを指示に合致するように変換して、音片編集部8に供給する。具体的には、例えば、検索部9より供給された音片データの元の時間長を、索出されたスピード初期値データに基づいて特定した上、この音片データをリサンプリングして、この音片データのサンプル数を、音片編集部8の指示したスピードに合致する時間長にすればよい。

[0054]

また、話速変換部11は、検索部9より供給された音片読みデータ及びピッチ成分データも音片編集部8に供給し、欠落部分識別データを検索部9より供給された場合は、更にこの欠落部分識別データも音片編集部8に供給する。

[0055]


なお、発声スピードデータが音片編集部8に供給されていない場合、音片編集部8は、話速変換部11に対し、話速変換部11に供給された音片データを変換せずに音片編集部8に供給するよう指示すればよく、話速変換部11は、この指示に応答し、検索部9より供給された音片データをそのまま音片編集部8に供給すればよい。


[0056]

音片編集部 8 は、話速変換部 1 1 より音片データ、音片読みデータ及びピッチ成分データを供給されると、供給された音片データのうちから、定型メッセージを構成する音片の波形に近似できる波形を表す音片データを、音片 1 個につき 1 個ずつ選択する。ただし、音片編集部 8 は、いかなる条件を満たす波形を定型メッセージの音片に近い波形とするかを、取得した照合レベルデータに従って設定する。

[0057]

具体的には、まず、音片編集部 8 は、定型メッセージデータが表す定型メッセージに、例えば「藤崎モデル」や「ToBI (Tone and Break Indices)」等の 韻律予測の手法に基づいた解析を加えることにより、この定型メッセージの韻律





[0058]

次に、音片編集部8は、例えば、

(1) 照合レベルデータの値が「1」である場合は、話速変換部11より供給された音片データ(すなわち、定型メッセージ内の音片と読みが合致する音片データ)をすべて、定型メッセージ内の音片の波形に近いものとして選択する。

[0059]

(2) 照合レベルデータの値が「2」である場合は、(1)の条件(つまり、読みを表す表音文字の合致という条件)を満たし、更に、音片データのピッチ成分の周波数の時間変化を表すピッチ成分データの内容と定型メッセージに含まれる音片のアクセントの予測結果との間に所定量以上の強い相関がある場合(例えば、アクセントの位置の時間差が所定量以下である場合)に限り、この音片データが定型メッセージ内の音片の波形に近いものとして選択する。なお、定型メッセージ内の音片のアクセントの予測結果は、定型メッセージの韻律の予測結果より特定できるものであり、音片編集部8は、例えば、ピッチ成分の周波数が最も高いと予測されている位置をアクセントの予測位置であると解釈すればよい。一方、音片データが表す音片のアクセントの位置については、例えば、ピッチ成分の周波数が最も高い位置を上述のピッチ成分データに基づいて特定し、この位置をアクセントの位置であると解釈すればよい。

[0060]

(3) 照合レベルデータの値が「3」である場合は、(2)の条件(つまり、読みを表す表音文字及びアクセントの合致という条件)を満たし、更に、音片データが表す音声の鼻濁音化や無声化の有無が、定型メッセージの韻律の予測結果に合致している場合に限り、この音片データが定型メッセージ内の音片の波形に近いものとして選択する。音片編集部8は、音片データが表す音声の鼻濁音化や無声化の有無を、話速変換部11より供給されたピッチ成分データに基づいて判別すればよい。

[0061]

なお、音片編集部8は、自ら設定した条件に合致する音片データが1個の音片

につき複数あった場合は、これら複数の音片データを、設定した条件より厳格な 条件に従って1個に絞り込むものとする。

[0062]

具体的には、例えば、設定した条件が照合レベルデータの値「1」に相当するものであって、該当する音片データが複数あった場合は、照合レベルデータの値「2」に相当する検索条件にも合致するものを選択し、なお複数の音片データが選択された場合は、選択結果のうちから照合レベルデータの値「3」に相当する検索条件にも合致するものを更に選択する、等の操作を行う。照合レベルデータの値「3」に相当する検索条件で絞り込んでなお複数の音片データが残る場合は、残ったものを任意の基準で1個に絞り込めばよい。

[0063]

一方、音片編集部 8 は、話速変換部 1 1 より欠落部分識別データも供給されている場合には、欠落部分識別データが示す音片の読みを表す表音文字列を定型メッセージデータより抽出して音響処理部 4 に供給し、この音片の波形を合成するよう指示する。

[0064]

指示を受けた音響処理部4は、音片編集部8より供給された表音文字列を、配信文字列データが表す表音文字列と同様に扱う。この結果、この表音文字列に含まれる表音文字が示す音声の波形を表す圧縮波形データが検索部5により索出され、この圧縮波形データが伸長部6により元の波形データへと復元され、検索部5を介して音響処理部4へと供給される。音響処理部4は、この波形データを音片編集部8へと供給する。

[0065]

音片編集部 8 は、音響処理部 4 より波形データを返送されると、この波形データと、話速変換部 1 1 より供給された音片データのうち音片編集部 8 が選択したものとを、定型メッセージデータが示す定型メッセージ内での各音片の並びに従った順序で互いに結合し、合成音声を表すデータとして出力する。

[0066]

なお、話速変換部11より供給されたデータに欠落部分識別データが含まれて



いない場合は、音響処理部4に波形の合成を指示することなく直ちに、音片編集部8が選択した音片データを、定型メッセージデータが示す定型メッセージ内での各音片の並びに従った順序で互いに結合し、合成音声を表すデータとして出力すればよい。

[0067]

以上説明した、この音声合成システムでは、音素より大きな単位であり得る音片の波形を表す音片データが、韻律の予測結果に基づいて、録音編集方式により自然につなぎ合わせられ、定型メッセージを読み上げる音声が合成される。音片データベース10の記憶容量は、音素毎に波形を記憶する場合に比べて小さくでき、また、高速に検索できる。このため、この音声合成システムは小型軽量に構成することができ、また高速な処理にも追随できる。

[0068]

なお、この音声合成システムの構成は上述のものに限られない。

例えば、波形データや音片データはPCM形式のデータである必要はなく、データ形式は任意である。

また、波形データベース 7 や音片データベース 1 0 は波形データや音片データを必ずしもデータ圧縮された状態で記憶している必要はない。波形データベース 7 や音片データベース 1 0 が波形データや音片データをデータ圧縮されていない状態で記憶している場合、本体ユニットMは伸長部 6 を備えている必要はない。

[0069]

また、音片データベース作成部13は、図示しない記録媒体ドライブ装置にセットされた記録媒体から、この記録媒体ドライブ装置を介して、音片データベース10に追加する新たな圧縮音片データの材料となる音片データや表音文字列を読み取ってもよい。

また、音片登録ユニットRは、必ずしも収録音片データセット記憶部12を備えている必要はない。

[0070]

また、ピッチ成分データは音片データが表す音片のピッチ長の時間変化を表す データであってもよい。この場合、音片編集部8は、ピッチ長が最も短い位置を ピッチ成分データに基づいて特定し、この位置をアクセントの位置であると解釈 すればよい。

[0071]

また、音片編集部 8 は、特定の音片の韻律を表す韻律登録データをあらかじめ記憶し、定型メッセージにこの特定の音片が含まれている場合は、この韻律登録データが表す韻律を、韻律予測の結果として扱うようにしてもよい。

また、音片編集部8は、過去の韻律予測の結果を韻律登録データとして新たに 記憶するようにしてもよい。

[0072]

また、音片データベース作成部13は、マイクロフォン、増幅器、サンプリング回路、A/D (Analog-to-Digital) コンバータ及びPCMエンコーダなどを備えていてもよい。この場合、音片データベース作成部13は、収録音片データセット記憶部12より音片データを取得する代わりに、自己のマイクロフォンが集音した音声を表す音声信号を増幅し、サンプリングしてA/D変換した後、サンプリングされた音声信号にPCM変調を施すことにより、音片データを作成してもよい。


[0073]

また、音片編集部 8 は、音響処理部 4 より返送された波形データを話速変換部 1 1 に供給することにより、当該波形データが表す波形の時間長を、発声スピードデータが示すスピードに合致させるようにしてもよい。

[0074]

また、音片編集部 8 は、例えば、言語処理部 1 と共にフリーテキストデータを取得し、このフリーテキストデータが表すフリーテキストに含まれる音片の波形に近い波形を表す音片データを、定型メッセージに含まれる音片の波形に近い波形を表す音片データを選択する処理と実質的に同一の処理を行うことによって選択して、音声の合成に用いてもよい。

この場合、音響処理部4は、音片編集部8が選択した音片データが表す音片については、この音片の波形を表す波形データを検索部5に索出させなくてもよい。なお、音片編集部8は、音響処理部4が合成しなくてよい音片を音響処理部4



[0075]

また、音片編集部 8 は、例えば、音響処理部 4 と共に配信文字列データを取得し、この配信文字列データが表す配信文字列に含まれる音片の波形に近い波形を表す音片データを、定型メッセージに含まれる音片の波形に近い波形を表す音片データを選択する処理と実質的に同一の処理を行うことによって選択して、音声の合成に用いてもよい。この場合、音響処理部 4 は、音片編集部 8 が選択した音片データが表す音片については、この音片の波形を表す波形データを検索部 5 に索出させなくてもよい。

[0076]

以上、この発明の実施の形態を説明したが、この発明にかかる音声合成装置は、専用のシステムによらず、通常のコンピュータシステムを用いて実現可能である。

例えば、パーソナルコンピュータに上述の言語処理部1、一般単語辞書2、ユーザ単語辞書3、音響処理部4、検索部5、伸長部6、波形データベース7、音片編集部8、検索部9、音片データベース10及び話速変換部11の動作を実行させるためのプログラムを格納した媒体(CD-ROM、MO、フロッピー(登録商標)ディスク等)から該プログラムをインストールすることにより、上述の処理を実行する本体ユニットMを構成することができる。

また、パーソナルコンピュータに上述の収録音片データセット記憶部12、音片データベース作成部13及び圧縮部14の動作を実行させるためのプログラムを格納した媒体から該プログラムをインストールすることにより、上述の処理を実行する音片登録ユニットRを構成することができる。

[0077]

そして、これらのプログラムを実行し本体ユニットMや音片登録ユニットRとして機能するパーソナルコンピュータが、図1の音声合成システムの動作に相当する処理として、図3~図5に示す処理を行うものとする。

図3は、このパーソナルコンピュータがフリーテキストデータを取得した場合




図4は、このパーソナルコンピュータが配信文字列データを取得した場合の処理を示すフローチャートである。

図5は、このパーソナルコンピュータが定型メッセージデータ及び発声スピードデータを取得した場合の処理を示すフローチャートである。

[0078]

すなわち、このパーソナルコンピュータが、外部より、上述のフリーテキストデータを取得すると(図3、ステップS101)、このフリーテキストデータが表すフリーテキストに含まれるそれぞれの表意文字について、その読みを表す表音文字を、一般単語辞書2やユーザ単語辞書3を検索することにより特定し、この表意文字を、特定した表音文字へと置換する(ステップS102)。なお、このパーソナルコンピュータがフリーテキストデータを取得する手法は任意である

[0079]

そして、このパーソナルコンピュータは、フリーテキスト内の表意文字をすべて表音文字へと置換した結果を表す表音文字列が得られると、この表音文字列に含まれるそれぞれの表音文字について、当該表音文字が表す単位音声の波形を波形データベース7より検索し、表音文字列に含まれるそれぞれの表音文字が表す単位音声の波形を表す圧縮波形データを索出する(ステップS103)。

[0800]

次に、このパーソナルコンピュータは、索出された圧縮波形データを、圧縮される前の波形データへと復元し(ステップS104)、復元された波形データを、表音文字列内での各表音文字の並びに従った順序で互いに結合し、合成音声データとして出力する(ステップS105)。なお、このパーソナルコンピュータが合成音声データを出力する手法は任意である。

[0081]

また、このパーソナルコンピュータが、外部より、上述の配信文字列データを 任意の手法で取得すると(図4、ステップS201)、この配信文字列データが 表す表音文字列に含まれるそれぞれの表音文字について、当該表音文字が表す単 位音声の波形を波形データベース7より検索し、表音文字列に含まれるそれぞれの表音文字が表す単位音声の波形を表す圧縮波形データを索出する (ステップS 202)。

[0082]

次に、このパーソナルコンピュータは、索出された圧縮波形データを、圧縮される前の波形データへと復元し(ステップS203)、復元された波形データを、表音文字列内での各表音文字の並びに従った順序で互いに結合し、合成音声データとしてステップS105の処理と同様の処理により出力する(ステップS204)。

[0083]

一方、このパーソナルコンピュータが、外部より、上述の定型メッセージデータ及び発声スピードデータを任意の手法により取得すると(図5、ステップS301)、まず、この定型メッセージデータが表す定型メッセージに含まれる音片の読みを表す表音文字に合致する表音文字が対応付けられている圧縮音片データをすべて索出する(ステップS302)。

[0084]

また、ステップS302では、該当する圧縮音片データに対応付けられている 上述の音片読みデータ、スピード初期値データ及びピッチ成分データも索出する 。なお、1個の音片につき複数の圧縮音片データが該当する場合は、該当する圧 縮音片データすべてを索出する。一方、圧縮音片データを索出できなかった音片 があった場合は、上述の欠落部分識別データを生成する。

[0085]

次に、このパーソナルコンピュータは、索出された圧縮音片データを、圧縮される前の音片データへと復元する(ステップS303)。そして、復元された音片データを、上述の音片編集部8が行う処理と同様の処理により変換して、当該音片データが表す音片の時間長を、発声スピードデータが示すスピードに合致させる(ステップS304)。なお、発声スピードデータが供給されていない場合は、復元された音片データを変換しなくてもよい。

[0086]

次に、このパーソナルコンピュータは、定型メッセージデータが表す定型メッセージに韻律予測の手法に基づいた解析を加えることにより、この定型メッセージの韻律を予測する(ステップS305)。そして、音片の時間長が変換された音片データのうちから、定型メッセージを構成する音片の波形に最も近い波形を表す音片データを、上述の音片編集部8が行う処理と同様の処理を行うことにより、外部より取得した照合レベルデータが示す基準に従って、音片1個につき1個ずつ選択する(ステップS306)。

[0087]

具体的には、ステップS306でこのパーソナルコンピュータは、例えば、上述した(1)~(3)の条件に従って音片データを特定する。すなわち、照合レベルデータの値が「1」である場合は、定型メッセージ内の音片と読みが合致する音片データをすべて、定型メッセージ内の音片の波形を表しているとみなす。また、照合レベルデータの値が「2」である場合は、読みを表す表音文字が合致し、更に、音片データのピッチ成分の周波数の時間変化を表すピッチ成分データの内容が定型メッセージに含まれる音片のアクセントの予測結果に合致する場合に限り、この音片データが定型メッセージ内の音片の波形を表しているとみなす。また、照合レベルデータの値が「3」である場合は、読みを表す表音文字及びアクセントが合致し、更に、音片データが表す音声の鼻濁音化や無声化の有無が、定型メッセージの韻律の予測結果に合致している場合に限り、この音片データが定型メッセージ内の音片の波形を表しているとみなす。

なお、照合レベルデータが示す基準に合致する音片データが1個の音片につき 複数あった場合は、これら複数の音片データを、設定した条件より厳格な条件に 従って1個に絞り込むものとする。

[0088]

一方、このパーソナルコンピュータは、欠落部分識別データを生成した場合、 欠落部分識別データが示す音片の読みを表す表音文字列を定型メッセージデータ より抽出し、この表音文字列につき、音素毎に、配信文字列データが表す表音文 字列と同様に扱って上述のステップS 2 0 2~S 2 0 3 の処理を行うことにより 、この表音文字列内の各表音文字が示す音声の波形を表す波形データを復元する

ページ: 25/

(ステップS307)。

[0089]

そして、このパーソナルコンピュータは、復元した波形データと、ステップS306で選択した音片データとを、定型メッセージデータが示す定型メッセージ内での各音片の並びに従った順序で互いに結合し、合成音声を表すデータとして出力する(ステップS308)。

[0090]

なお、パーソナルコンピュータに本体ユニットMや音片登録ユニットRの機能を行わせるプログラムは、例えば、通信回線の掲示板(BBS)にアップロードし、これを通信回線を介して配信してもよく、また、これらのプログラムを表す信号により搬送波を変調し、得られた変調波を伝送し、この変調波を受信した装置が変調波を復調してこれらのプログラムを復元するようにしてもよい。

そして、これらのプログラムを起動し、OSの制御下に、他のアプリケーションプログラムと同様に実行することにより、上述の処理を実行することができる

[0091]

なお、OSが処理の一部を分担する場合、あるいは、OSが本願発明の1つの構成要素の一部を構成するような場合には、記録媒体には、その部分を除いたプログラムを格納してもよい。この場合も、この発明では、その記録媒体には、コンピュータが実行する各機能又はステップを実行するためのプログラムが格納されているものとする。

[0092]

【発明の効果】

以上説明したように、この発明によれば、簡単な構成で高速に自然な合成音声 を得るための音声合成装置、音声合成方法及びプログラムが実現される。

【図面の簡単な説明】

【図1】

この発明の実施の形態に係る音声合成システムの構成を示すプロック図である

【図2】

音片データベースのデータ構造を模式的に示す図である。

【図3】

この発明の実施の形態に係る音声合成システムの機能を行うパーソナルコンピュータがフリーテキストデータを取得した場合の処理を示すフローチャートである。

【図4】

この発明の実施の形態に係る音声合成システムの機能を行うパーソナルコンピュータが配信文字列データを取得した場合の処理を示すフローチャートである。

【図5】

この発明の実施の形態に係る音声合成システムの機能を行うパーソナルコンピュータが定型メッセージデータ及び発声スピードデータを取得した場合の処理を示すフローチャートである。

【符号の説明】

| M | 本体ユニット |
|-----|---------------|
| 1 | 言語処理部 |
| 2 | 一般単語辞書 |
| 3 | ユーザ単語辞書 |
| 4 | 音響処理部 |
| 5 | 検索部 |
| 6 | 伸長部 |
| 7 | 波形データベース |
| 8 | 音片編集部 |
| 9 | 検索部 |
| 1 0 | 音片データベース |
| 1 1 | 話速変換部 |
| R | 音片登録ユニット |
| 1 2 | 収録音片データセット記憶部 |
| 1 3 | 音片データベース作成部 |


14 圧縮部

HDR ヘッダ部


IDX インデックス部

DIR ディレクトリ部


DAT データ部




【図1】




【図2】














ページ: 1/E

【書類名】 要約書

【要約】

【課題】 簡単な構成で高速に自然な合成音声を得るための音声合成装置等を提供することである。

【解決手段】 定型メッセージを表すデータが供給されると、音片編集部8は、定型メッセージ内の音片と読みが合致する音片の音片データを音片データベース10から索出させ、発声スピードデータが示すスピードに合致するよう、この音片データを変換させる。一方で音片編集部8は定型メッセージの韻律予測を行い、索出された音片データのうちから定型メッセージ内の各音片に最もよく合致するものを1個ずつ、韻律予測結果に基づいて選択する。選択できなかった音片については音響処理部4に単位音声毎の波形を表す波形データを供給させる。そして、選択した音片データや、音響処理部4に供給させた波形データを互いに結合して、合成音声を表すデータを生成する。

【選択図】 図1

特願2003-160657

出願人履歴情報

識別番号

[000003595]

1. 変更年月日

2002年 7月26日

[変更理由]

住所変更

住 所

東京都八王子市石川町2967番地3

氏 名

株式会社ケンウッド